

DESEMPENHO DO CLASSIFICADOR RANDOM FOREST NA DETECÇÃO DE CLASSES DE USO E COBERTURA DA TERRA EM ÁREA DE CERRADO

Leticia Ferreira da Silva ¹

João Alberto Fischer Filho ²

Bruno Enrique Fuzzo ³

Daniela Fernanda da Silva Fuzzo ⁴

Uso de tecnologia para monitoramento ambiental

Resumo

As geotecnologias vêm se mostrando promissoras para aplicação da prática na análise de dados ambientais. O manejo adequado dos recursos naturais em ambientes frágeis, como o Cerrado, requer o conhecimento de suas propriedades e distribuição espacial. Desta forma o objetivo foi avaliar o desempenho do classificador Random Forest utilizando imagens do satélite Landsat 5/TM e 8/OLI, na detecção de classes de uso e cobertura da terra, para o anos de 2005 e 2022, na microrregião do município de Frutal/MG. A metodologia foi executada utilizando aprendizado de máquina para classificação supervisionada (Random Forest) disponível na plataforma Google Earth Engine (GEE). Foram selecionadas as imagens, a geração de mosaicos, a coleta de pontos amostrais, seleção de bandas e classificação, pós-classificação e avaliação do modelo. A partir do cruzamento entre amostras de referência e mapas classificados foi possível gerar as métricas de acurácia. O desempenho do método foi analisado por meio dos coeficientes de Exatidão Global (EG), calculados a partir dos dados da matriz de confusão correspondente à verdade terrestre. Os valores do coeficiente de EG foram de: 0,80% para o ano de 2005 e 0,97% para o ano de 2022. Os resultados demonstraram que o classificador baseado em árvore de decisão Random Forest (RF), apresentou bons resultados na classificação. A plataforma Google Earth Engine demonstrou desempenho satisfatório em termos de processamento computacional, possibilitando o estudo de dados ambientais em larga escala, permitindo a identificação de mudanças no uso e cobertura do solo.

Palavras-chave: Google Earth Engine, Sensoriamento Remoto, Geoprocessamento, Meio Ambiente

¹ Graduanda do curso de Geografia – Universidade do Estado de Minas Gerais – UEMG – Unidade Frutal. Email: leticia.1093292@discente.uemg.br

² Prof. Dr. João Alberto Fischer Filho, . Univeridade do Estado de Minas Gerais – UEMG – Unidade Frutal. Departamento de Ciências Agrárias e Biológicas: Email: joao.fischer@uemg.br

³ Mestrando do Programa de Pós Graduação em Ciências Ambientais -CIAMB /UEMG. Universidade do Estado de Minas Gerais – UEMG – Unidade Frutal. Emal: bruno_fuzzo@yahoo.com.br.

⁴ Profa. Dra. Daniela Fernanda da Silva Fuzzo. Univeridade do Estado de Minas Gerais – UEMG – Unidade Frutal. Departamento de Ciências Agrárias e Biológicas. Email: daniela.fuzzo@uemg.br

INTRODUÇÃO

Diante da intensa e constante ação antrópica que vem ameaçando os biomas brasileiros, o monitoramento sistemático da microregião do município de Frutal-MG, torna-se uma medida indispensável. A exploração descontrolada dos recursos naturais, a expansão da agricultura e a urbanização desordenada têm colocado em risco a integridade ecológica desse ambiente. Nesse sentido, o acompanhamento detalhado das mudanças no uso e na cobertura da terra é fundamental para entender a real dimensão dos impactos causados pela ação humana. O monitoramento regular não apenas permite a identificação precoce de áreas vulneráveis, como também oferece subsídios para ações de conservação que considerem a preservação da biodiversidade. É essencial, portanto, que essas iniciativas sejam baseadas em dados precisos e atualizados, capazes de orientar medidas sustentáveis que garantam a proteção do bioma e promovam um equilíbrio entre as atividades humanas e a conservação ambiental. Somente assim será possível assegurar a continuidade dos serviços ecossistêmicos prestados por este bioma, que são essenciais para o equilíbrio ecológico e para a qualidade de vida das populações que dele dependem.

O Cerrado é o segundo maior Bioma do Brasil, com área de cobertura de aproximadamente 24% do território brasileiro, ficando atrás somente da Floresta Amazônica (IBGE, 2018). representa a maior savana na América do Sul e possui a maior diversidade biológica do mundo, porém devido às ameaças provocadas pelas intervenções humana é considerado um dos hotspots globais para a conservação da biodiversidade. Devido as grandes transformações no últimos anos, o Cerrado perdeu metade de sua área para as terras relacionadas às atividades agrícolas (STRASSBURG et al., 2017; ALENCAR et al., 2020).

Com o surgimento de satélites digitais mais avançados e a contínua evolução das técnicas de sensoriamento remoto, a necessidade de realizar análises mais acuradas cresceu exponencialmente, acompanhando o avanço da tecnologia (CONGALTON, 1991). Esses avanços permitem a obtenção de imagens com maior precisão, o que possibilita uma análise mais detalhada das mudanças no uso e cobertura da terra. As imagens de sensoriamento remoto, especialmente aquelas de alta resolução espacial, continuam sendo uma das principais fontes de dados para a classificação e monitoramento da cobertura e uso da terra. Sua aplicação vai desde estudos de impactos ambientais até o planejamento de políticas de conservação (ALVARENGA et al., 2016; ALDIANSYAH e SAPUTRA, 2023). Essa alta resolução permite distinguir com maior clareza diferentes tipos de cobertura vegetal e áreas urbanizadas,

facilitando a tomada de decisões em diversas áreas, como agricultura, planejamento urbano e conservação ambiental.

Os classificadores supervisionados, como as redes neurais e as máquinas de vetor de suporte, têm se mostrado ferramentas altamente eficazes nesse processo, pois são capazes de aprender as características das amostras fornecidas no treinamento e aplicar esse aprendizado a dados não classificados (BELGIU e DRAGUT, 2016). Isso significa que, após serem treinados com dados de referência, esses algoritmos podem identificar padrões em grandes volumes de dados, gerando resultados mais precisos e confiáveis. O classificador Random Forest baseia-se no princípio de árvores de decisão, onde amostras selecionadas aleatoriamente, com reposição, são utilizadas como variáveis preditivas para treinar o modelo de classificação (CHO et al., 2021).

Cada árvore dentro do Random Forest é construída a partir de um subconjunto aleatório dos dados, e as previsões finais são obtidas pela média ou pela votação majoritária das árvores individuais, o que reduz o risco de overfitting e melhora a precisão do modelo. Nos últimos anos, o uso do Random Forest (BREIMAN, 2001; SHELESTOV et al., 2017) tornou-se amplamente popular na comunidade de sensoriamento remoto, devido à sua capacidade de produzir classificações confiáveis com um nível elevado de acurácia.

Uma das principais vantagens do Random Forest é a velocidade de processamento, sendo eficaz tanto em pequenas quanto em grandes bases de dados, o que é particularmente relevante em aplicações de sensoriamento remoto, onde grandes volumes de dados são frequentemente analisados. Além disso, o Random Forest tem a capacidade de lidar com dados altamente complexos, selecionando e classificando automaticamente as variáveis com maior capacidade de discriminar as classes-alvo, tornando-o uma ferramenta poderosa para a classificação de imagens de cobertura e uso da terra (ZURQANI et al., 2018; WAGNER et al., 2019).

Outra característica importante do Random Forest é sua robustez ao lidar com dados ruidosos ou incompletos, o que o torna uma escolha ideal para estudos em que a qualidade dos dados pode variar. Sua habilidade de trabalhar com diferentes tipos de variáveis, sejam elas contínuas ou categóricas, também aumenta sua flexibilidade e aplicabilidade em diversas áreas de pesquisa. Essa combinação de precisão, velocidade e capacidade de lidar com variáveis complexas e ruidosas fez do Random Forest um dos classificadores mais utilizados em sensoriamento remoto e em outras disciplinas que exigem análise de grandes volumes de dados com alta confiabilidade (RODRIGUEZ-GALIANO et al., 2012; DU et al., 2015)

Tais avanços são fundamentais para estudos ambientais, pois permitem a criação de bases de

dados robustas e atualizadas, essenciais para a formulação de políticas públicas, monitoramento de desmatamento e conservação de ecossistemas. Essas ferramentas, associadas a dados de sensoriamento remoto de alta qualidade, têm transformado o campo da geoinformação, fornecendo subsídios para um planejamento mais sustentável e eficiente em escala global.

Com o acesso às tecnologias de processamento de grandes volumes de dados, a computação em nuvem se mostra uma solução na área de geoprocessamento, o que possibilita a análise de dados complexos. O objetivo deste trabalho foi avaliar o desempenho do classificador Random Forest na classificação de uso e cobertura da terra para a microrregião de Frutal – MG, nos anos de 2005 e 2022.

METODOLOGIA

O universo de análise engloba a Microrregião do município de Frutal, localizada no estado de Minas Gerais, especificamente na região oeste da Mesorregião do Triângulo Mineiro e Alto Paranaíba (Triângulo Sul) nas coordenadas de latitude: entre 19°30' S e 20°00' S e longitude: entre 49°30' O e 50°00' O., como indicado na Figura 1. Essa microrregião se destaca pela sua diversidade geográfica e climática, o que favorece uma ampla variedade de atividades agropecuárias. A economia local é amplamente baseada na agropecuária e na agricultura, como soja e milho, e na cana-de-açúcar.

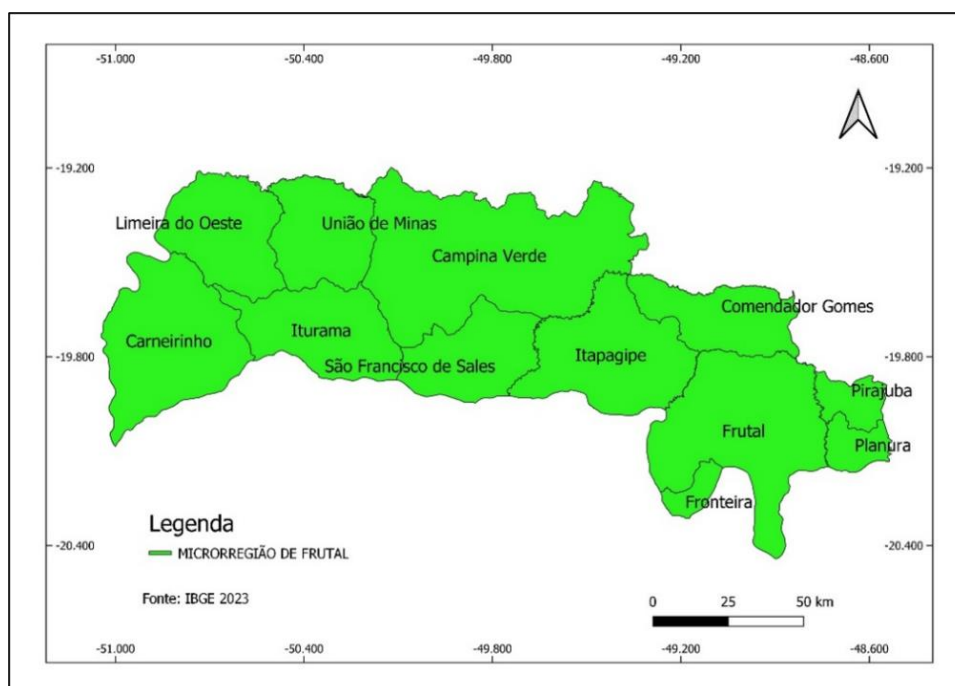


Figura 01: Localização da área de estudo

Os dados foram processados e executados pelo Code Editor do GEE à partir do script desenvolvido na linguagem JavaScript. No que se diz respeito à coleção de imagens Landsat, os produtos utilizados foram o Landsat 5/TM Collection 2 Tier 1 TOA Reflectance e o Landsat/8 Collection 2 Tier 1 and Real-Time data TOA Reflectance. Foram analisados as imagens entre os meses de junho e julho para a aquisição das imagens se justifica pela menor incidência de cobertura de nuvens, uma vez que este período coincide com índices pluviométricos reduzidos e menor atividade convectiva, resultando em melhores condições para a captação de dados de alta qualidade FISCH, G. et al. (1998).

Nas imagens foram aplicados os algoritmos de remoção de nuvens (Cloud detector) com base na probabilidade de ocorrência destas, permitindo a extração de informações mais precisas das superfícies terrestres. Esse processo é fundamental para garantir que a análise espectral não seja comprometida pela interferência atmosférica, como a presença de nuvens que podem distorcer os dados.

Após a geração dos mosaicos, a primeira etapa consistiu na interpretação visual dos alvos presentes na imagem a partir de características como forma, textura e cor, na sequência foram consideradas as composições coloridas RGB321 e RGB543, e, assim, foram definidas as classes de cobertura da terra para a coleta das amostras de treinamento. A segunda etapa consistiu na coleta de treinamento (amostras), para as seguintes classes de uso e cobertura do solo: : floresta, pastagem, agrícola, área não vegetada e corpo d'água. A classificação dos mosaicos foi realizada utilizando o algoritmo Random Forest, um dos métodos mais eficazes para este tipo de análise (BELGIU; DRAGUT, 2016), devido à sua robustez e capacidade de lidar com grandes volumes de dados. Com a finalidade de treinar os classificadores, para cada uma das classes foram colhidas 100 amostras manualmente. A partir dessas amostras, o classificador as separa em subconjuntos de acordo com seus valores (SARTORIO et al., 2023). AS imagens classificadas foram expostas para o ambiente SIG (Sistema de Informação Geográfica) por meio do software QGIS 3.16.

Para avaliar o desempenho do classificador Random Forest e a confiabilidade da classificação, haja vista que não houve validação dos dados em campo, o trabalho utilizou Matriz de Confusão (*Confusion Matrix*) e a Precisão Global (*Overall Accuracy*), como apontam STEHMAN E FOODY (2019) e CONGALTON eGREEN (2019). A matriz de confusão apresenta o número de pixels classificados corretamente em oposição ao número de pixels previstos para cada classe no decorrer da classificação. Esta matriz permite obter informação da precisão global do respectivo classificador. A matriz de confusão permite observar na diagonal dos pares concordantes dos pontos na comparação entre o resultado da classificação a partir da imagem de satélite e as classes coletadas em campo. Já as demais células da matriz de confusão indicam o total dos pares que não há concordância dos pontos na

comparação De acordo com a Figura 2, é possível observar o fluxograma metodológico da pesquisa.

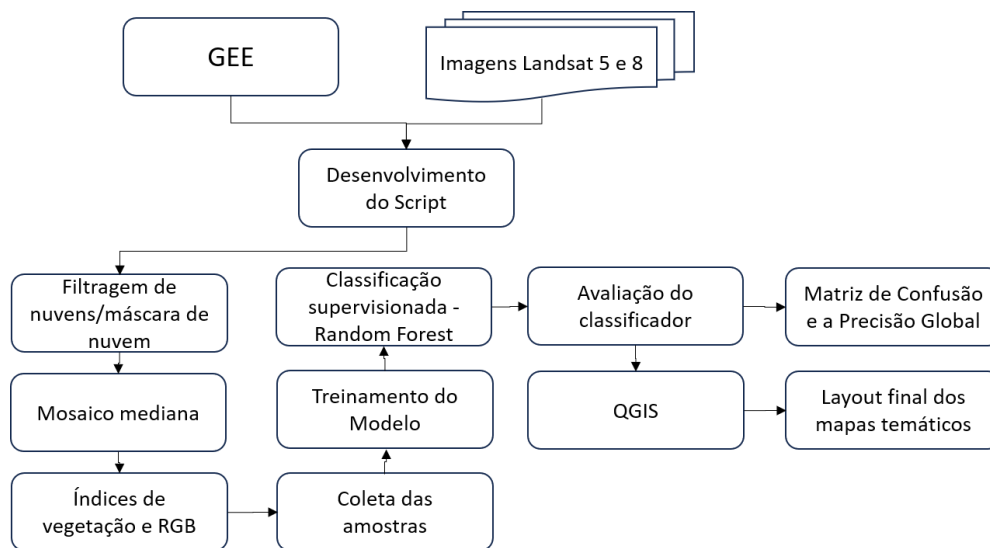


Figura 02: Fluxograma geral.

RESULTADOS E DISCUSSÃO

Ao analisar as áreas das classes de uso e cobertura da terra na microrregião de Frutal-MG entre os anos de 2005 e 2022, conforme apresentado na Tabela 1, foram observadas mudanças significativas nas principais classes analisadas. As Áreas de Preservação Permanente (APP) e Florestas registraram uma diminuição de 9%, correspondendo a uma perda de 270.571 km², passando de 3.154.149 km² em 2005 para 2.883.578 km² em 2022. A classe Pastagem também sofreu uma retração expressiva, com uma redução de 359.787 km², ou 6%, no mesmo período, o que reflete a substituição desse tipo de cobertura por outros usos da terra, corrobora trabalho de BRITO et al. (2012).

Tabela 01: Classificação de diferentes usos da terra.

Classes	2005		Dif	%
	2022 (km ²)	(km ²)		
APP e Florestas	2883578	3154149	-270571	-9
Pastagem	6141815	6501602	-359787	-6
Área agrícola	5579587	4529675	1049912	19
Área não vegetada	1520118	1876726	-356608	-23
Corpo d'água	714790	777735	-62945	-9

Por outro lado, as áreas destinadas à agricultura apresentaram um aumento considerável de 19%, correspondendo a um acréscimo de 1.049.912 km², passando de 4.529.675 km² em 2005 para 5.579.587 km² em 2022. As áreas não vegetadas, que englobam solo exposto e áreas urbanas, diminuíram 356.608 km², representando uma queda de 23%, o que pode estar relacionado com o avanço da urbanização e o aumento da infraestrutura na região. Os corpos d'água, que desempenham um papel crucial para o equilíbrio ecológico e para a oferta de recursos hídricos, também sofreram uma redução de 9%, ou 62.945 km², passando de 777.735 km² em 2005 para 714.790 km² em 2022. Essas transformações indicam um padrão de uso do solo voltado para a intensificação agrícola, com impactos potenciais sobre os recursos naturais e a sustentabilidade da paisagem regional. (PEREIRA et al., 2023; PATSALIDIS et al., 2019)

Na Figura 3 estão apresentados os resultados da classificação de uso e cobertura da terra pelo classificador Random Forest. Ao realizar uma análise visual dos resultados para o ano de 2005, observa-se a predominância da classe de pastagem, que cobre grande parte da área de estudo, destacada em amarelo no mapa, a figura evidencia também a distribuição espacial de outras classes, como as áreas de APP e Florestas, que aparecem em verde, concentradas em áreas fragmentadas e distribuídas de forma esparsa. Esta classe representa uma característica marcante do uso da terra na região, relacionada principalmente às atividades pecuárias que prevaleciam naquele período.

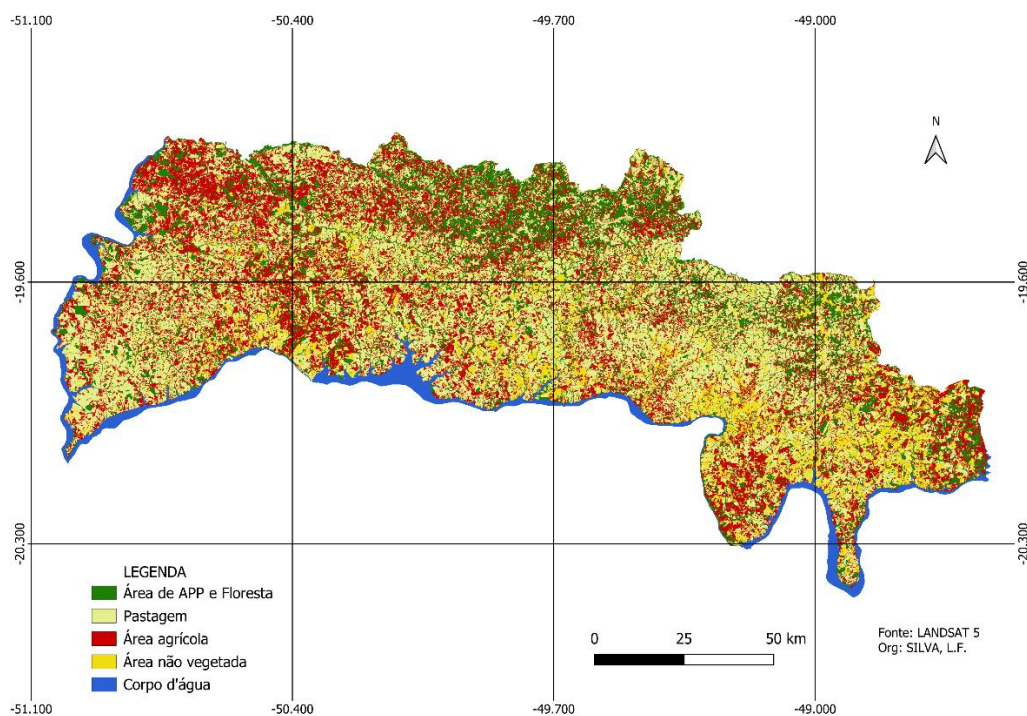


Figura 03: Classificação de uso e cobertura da terra para o ano de 2005.

Na Figura 4, para o ano de 2022 é possível observar que as áreas agrícolas, indicadas pela cor vermelha, já ocupam uma parte significativa da região, especialmente em áreas anteriormente ocupadas por pastagens e florestas. Esse aumento na extensão agrícola reflete as mudanças no uso da terra, impulsionadas pela intensificação da agricultura. As áreas de APP e Florestas, representadas em verde, aparecem de forma fragmentada ao longo da paisagem, geralmente em regiões de difícil acesso ou em áreas protegidas. No entanto, a presença dessas áreas está claramente diminuída em relação aos anos anteriores, apontando para uma tendência de desmatamento e conversão de florestas em áreas agrícolas.

Para a avaliação da metodologia utilizou-se inicialmente a determinação da matriz de erro para avaliar as divergências ocorridas entre as classes temáticas (CHAVES et al., 2020). A matriz de confusão permite observar na diagonal dos pares concordantes dos pontos na comparação entre o resultado da classificação a partir da imagem de satélite e as classes coletadas em campo. Já as demais células da matriz de confusão indicam o total dos pares que não há concordância dos pontos na comparação (PARENTE e FERREIRA, 2018).

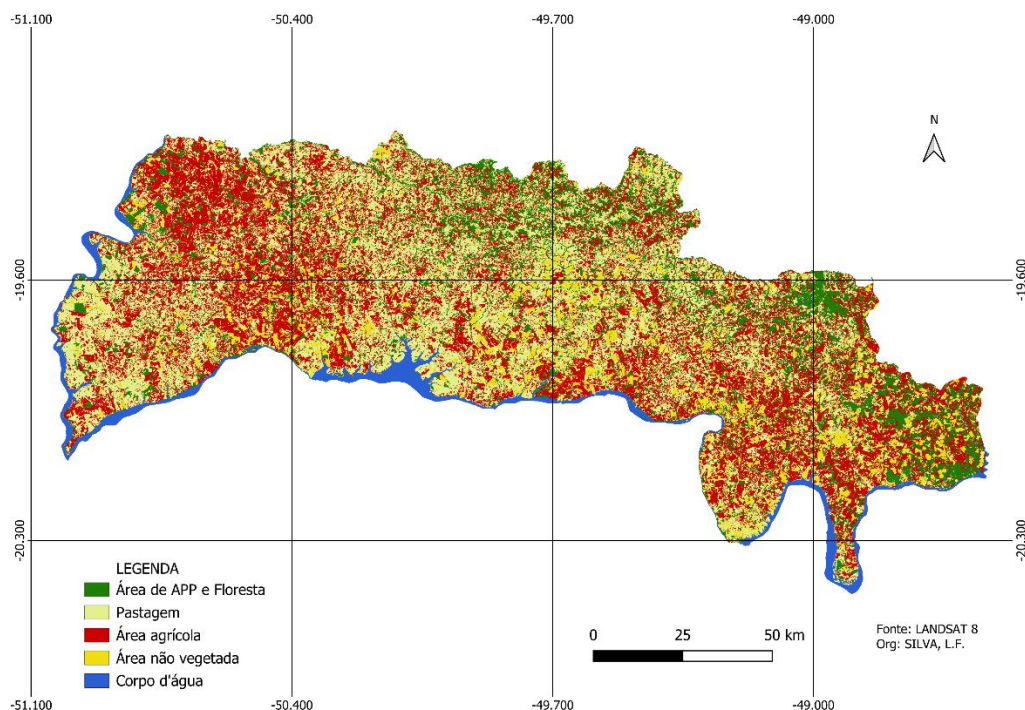


Figura 04: Classificação de uso e cobertura da terra para o ano de 2022.

Observando os resultados da avaliação da Precisão Global foram de 80% para o ano de 2005 e 97% para o ano de 2022, a análise da matriz de confusão do classificador, aplicado às imagens Landsat 5 para a microrregião de Frutal-MG, revela um desempenho satisfatório na classificação das diferentes classes. Área de APP e Florestas apresentaram uma boa taxa de acerto, com 13 amostras classificadas corretamente. No entanto, houve 2 erros de classificação, onde amostras dessa classe foram equivocadamente atribuídas à classe Área agrícola, o que pode ser justificado pela semelhança espectral entre essas duas classes em determinadas regiões.

A classe Pastagem também mostra um desempenho razoável, com 13 amostras corretamente classificadas. No entanto, 2 amostras foram erroneamente classificadas como Área de APP e Floresta, 3 como Área agrícola e 2 como Área não vegetada, sugerindo que há confusão entre áreas de pastagem e outras classes, especialmente áreas agrícolas, devido à sua proximidade ou características espectrais semelhantes.

A matriz de confusão resultante da classificação de imagens Landsat 8 (para o ano de 2022) mostra um desempenho muito preciso na distinção das classes, a classe Área de APP e Floresta

apresentou 27 amostras corretamente classificadas, sem erros de confusão com outras classes. Esse resultado indica uma excelente capacidade do modelo em identificar corretamente as áreas de preservação permanente e florestas, possivelmente devido à clara distinção espectral dessas áreas em relação às demais. Como mostram trabalhos de CARDOSO et al., 2021; CHELOTTI 2017; GRANDE E ALMEIDA CICERELLI 2016;) aplicados a outras áreas de Cerrado.

A classe Pastagem também mostra um bom desempenho, com 16 amostras classificadas corretamente. No entanto, houve um erro de confusão, onde uma amostra foi incorretamente classificada como Área não vegetada. Isso pode ser explicado pela presença de solo exposto em áreas de pastagem, o que pode causar confusão no modelo. A classe Área agrícola teve 14 amostras classificadas corretamente, com apenas uma confusão com a classe Pastagem. Isso sugere que, apesar da proximidade e, em alguns casos, semelhança espectral entre áreas agrícolas e de pastagem, o modelo foi capaz de discriminar bem essas classes.

CONCLUSÕES

O trabalho apresentou bons resultados na classificação realizada através do algoritmo Random Forest na plataforma Google Earth Engine, foi possível observar a distribuição espacial dessas classes e evidencia a transformação contínua do uso do solo ao longo dos anos, o que demanda uma abordagem de planejamento territorial que leve em consideração tanto o desenvolvimento econômico quanto a conservação ambiental. podemos concluir que o modelo demonstrou um desempenho altamente satisfatório. A precisão global foi elevada, com poucas confusões entre classes, o que evidencia a eficácia do método de classificação aplicado. Apesar de pequenos erros de confusão entre algumas classes, os resultados sugerem que este método é adequado para o monitoramento ambiental e pode ser melhorado com o uso de técnicas adicionais, como índices de vegetação específicos, ou o refinamento das classes de treinamento. Esses resultados reforçam o potencial do uso de dados de sensoriamento remoto para análises detalhadas de mudanças no uso da terra, fornecendo informações valiosas para o planejamento ambiental e agrícola.

AGRADECIMENTOS

Agradecemos à FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais) pelo apoio financeiro.

REFERÊNCIAS

- ALDIANSYAH, S.; SAPUTRA, R. A. Comparison of machine learning algorithms for land use and land cover analysis using Google Earth Engine (Case study: Wanggu watershed). *International Journal of Remote Sensing and Earth Sciences*, v. 19, n. 2, p. 197-210, 2023.
- ALENCAR, A., Z. SHIMBO, J., LENTI, F., BALZANI MARQUES, C., ZIMBRES, B., ROSA, M., BARROSO, M. Mapping three decades of changes in the brazilian savanna native vegetation using landsat data processed in the google earth engine platform. *Remote Sensing*, v. 12, n. 6, p. 924, 2020.
- ALVARENGA, L. A.; MELLO, C. R.; COLOMBO, A.; CUARTAS, L. A.; BOWLING, L. C. Assessment of land cover change on the hydrology of a Brazilian headwater watershed using the Distributed HydrologySoil-Vegetation Model. *Catena*, v. 143, p. 7-17, 2016.
- BELGIU, M.; DRAGUT, L. Random Forestin remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24 –31, 2016.
- BREIMAN, L. Random Forests. *Machine Learning*, Amsterdam, v. 45, p. 5–32, 2001.
- BRITO, J. L. S.; DOS REIS, L. N.G. Gonçalves. Mapeamento das áreas de conversão do uso da terra para cana-de-açúcar na mesorregião do Triângulo Mineiro/Alto Paranaíba-MG por meio de imagens TM/Landsat. *Revista Caminhos da Geografia*, v. 13, n. 41, p. 170-186, 2012.
- CARDOSO, P. V.; SEABRA, V. S.; XAVIER, R. A., RODRIGUES, E. M.; GOMES, A. S. Mapeamento de Áreas de Caatinga Através do Random Forrest: Estudo de caso na Bacia do Rio Taperoá. *Revista Geoaraguaia*, v. 11, p. 55-68, 2021.
- CHAVES, M. E. D.; PICOLI, M. C. A.; SANCHES, I. D. Recent applications of Landsat 8/OLI and Sentinel-2/MSI for land use and land cover mapping: A systematic review. *Remote Sensing*, v. 12, n. 18, e3062, 2020.
- CHO, D. F., SCHWAIDA, S. F., CICERELLI, R. E., ALMEIDA, T., RAMOS, A. P. M., & SANO, E. E. Desempenho do Algoritmo de Classificação de Imagens Random Forest para Mapeamento do Uso e Cobertura do Solo no Cerrado Brasileiro. 2021.
- CONGALTON R. G.; GREEN, K. *Assessing the Accuracy of Remotely Sensed Data*. 3ª ed. Taylor & Francis Group, 2019.
- DU, P., SAMAT, A., WASKE, B., LIU, S., LI, Z. Random Forestand rotation forest for fully polarized SAR image classification using polarimetric and spatial features. *ISPRS J. Photogramm. Remote Sensing*,v. 105, p. 38–53, 2015.

- FISCH, G.; MARENGO, J.A.; NOBRE, C.A. Uma revisão geral sobre o clima da Amazônia. *Acta amazônica*, v. 28, n. 2, p. 101-101, 1998.
- IBGE – Instituto Brasileiro de Geografia e Estatística. *Biomass e Sistema Costeiro-Marinho do Brasil: compatível com a escala 1:250.000*. Rio de Janeiro: IBGE, 2018.
- PATSALIDIS, S.; AGAPIOU, A.; HADJIMITSIS, D. G. Random Forest classification analysis of Sentinel-2 and Landsat-8 images over semi-arid environment in the Eastern Mediterranean. In: *International conference on geographic information, 2019. Proceedings...* Amsterdam: Springer, 2020.
- PEREIRA, P. R. M.; OLIVEIRA, M. M. N.; BOLFE, E. L.; MACARRINGUE, L. S. Comparação da classificação do uso e cobertura da terra em imagens Landsat-8 e Sentinel2 no Cerrado Maranhense. *GEOUERJ*, n. 42, e66306, 2023.
- RODRIGUEZ-GALIANO, V.F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M., RIGOL-SANCHEZ, J.P. An assessment of the effectiveness of a random forest classifier for landcover classification. *ISPRS J. Photogramm. Remote Sensing*, v. 67, p. 93–104, 2012.
- Sartorio, L. F., Varnier, M., Felipe, L. D. S., Zanotta, D. C., FREITAS, M., GRONDONA, A. Análise Comparativa Entre o Uso de Bandas Espectrais e o Uso da Análise de Componentes Principais (ACP) na Classificação de Uso e Cobertura da Terra. *Revista Brasileira de Cartografia*, v. 75, 2023.
- SHELESTOV, A.; LAVRENIUK, M.; KUSSUL, N.; NOVIKOV, A.; SKAKUN, S. Exploring Google Earth Engine platform for big data processing: Classification of multi-temporal satellite imagery for crop mapping. *Frontiers in Earth Science*, v. 5, 2017
- STEHMAN S. V.; FOODY G. M. Key issues in rigorous accuracy assessment of land cover products. *Remote Sensing of Environment*, v. 231 p. 1 – 23, 2019.
- STRASSBURG, B.B.N.; BROOKS, T.; FELTRAN-BARBIERI, R.; IRIBARREM, A.; CROUZEILLES, R.; LOYOLA, R.; LATAWIEC, A.E.; OLIVEIRA FILHO, F.J.B.; SCARAMUZZO, C.A.M.; SCARANO, F.R. Moment of truth for the Cerrado hotspot. *Nature Ecology & Evolution*, v. 1, p. 99, 2017.
- WAGNER, P. D.; BHALLAMUDI, S. M.; NARASIMHAN, B.; KUMAR, S.; FOHRER, N.; FIENER, P. Comparing the effects of dynamic versus static representations of land use change in hydrologic impact assessments. *Environmental Modelling & Software*, v. 122, e103987, 2019.
- ZURQANI, H. A., POST, C. J., MIKHAILOVA, E. A., SCHLAUTMAN, M. A., SHARP, J. L. Geospatial analysis of land use change in the Savannah River Basin using Google Earth Engine. *International journal of applied earth observation and geoinformation*, v. 69, p. 175-185, 2018.